

# Základy matematiky a statistiky pro humanitní obory II

Vojtěch Kovář

Fakulta informatiky, Masarykova univerzita  
Botanická 68a, 602 00 Brno, Czech Republic  
xkovar3@fi.muni.cz

část 9


# Obsah přednášky

- 1 Derivace
- 2 Integrál
- 3 Parciální derivace
- 4 Strojové učení
- 5 Neuronová síť

# Derivace

- Základní pojem **diferenciálního počtu**
- Směrnice tečny ke grafu funkce v určitém bodě
  - směrnice je číslo vyjadřující sklon přímky:  $y = ax + b$
  - definována přes limitu:  $f'(a) = \lim_{x \rightarrow a} \frac{f(x) - f(a)}{x - a}$
- Pro všechny body: nová (odvozená = derivovaná) funkce
  - např.  $f : y = x^2 \rightarrow f' : y = 2x$
  - např.  $f : y = 4x + 1 \rightarrow f' : y = 4$
- Využití: vyšetřování průběhu funkce
  - kladná derivace = funkce roste
  - záporná derivace = funkce klesá
  - nulová derivace = lokální minimum nebo maximum


# Příklad: derivace v tomto bodě je záporná



# Integrál

- Inverzní operace k derivaci
  - tzv. základní věta integrálního počtu
- Opět z dané funkce „vyrobíme“ jinou funkci
- Neurčitý integrál = primitivní funkce
  - množina funkcí, jejichž derivací dostaneme danou funkci
- Určitý integrál
  - změna primitivní funkce na daném intervalu
  - odpovídá ploše pod křivkou funkce
  - viz též Riemannův integrál
  - využití: výpočet obsahů, objemů, ...

# Určitý integrál: příklad



zdroj: [https://commons.wikimedia.org/wiki/File:Integral\\_as\\_region\\_under\\_curve.svg](https://commons.wikimedia.org/wiki/File:Integral_as_region_under_curve.svg)



# Parciální derivace


- U funkcí více proměnných
  - např.  $f : z = 4y - 2x + 5$
  - např.  $f : y = 4x_1 + 8x_2 + x_3 + 5x_4 - 8$
- Všechny proměnné až na jednu bereme jako konstanty
  - např.  $f(x, y) = 4y^2 - 2x + 5$
  - $\frac{df}{dy} = 8y$
  - $\frac{df}{dx} = 2$
  - směrnice tečny v bodě „ve směru dané osy”

# Strojové učení (supervised = s učitelem)

- Zobecnění z (mnoha) konkrétních příkladů
- 2 základní typy problémů:
  - Klasifikace
    - cílem je přiřadit objekt do třídy
    - na základě jeho atributů (tzv. **features**)
    - features jsou číselné nebo řetězcové hodnoty
    - často mluvíme o **vektoru hodnot**
    - např. „umět rozlišit jabka a hrušky na základě barvy a tvaru“
  - Regrese
    - cílem je na základě atributů přiřadit číselnou hodnotu
    - např. „na základě parametrů automobilu přiřadit cenu“



# Lineární regrese



# Lineární regrese

- Snažíme se co nejlépe proložit přímkou množinou bodů
  - např. ve dvourozměrném prostoru
  - přímka:  $y = ax + b$
  - snažíme se najít parametry  $a$  a  $b$
  - tak, abychom minimalizovali chybovou funkci (**loss function**)
- Chybová funkce  $e$ 
  - součet rozdílů (čtverců) odchylek od přímky
  - pro každou dvojici  $a$  a  $b$  dostaneme číselnou hodnotu chyby
  - $e$  je tedy funkcí dvou proměnných,  $a$  a  $b$
  - potřebujeme najít  $a$  a  $b$  tak, že chyba  $e(a, b)$  je minimální


# Lineární regrese

## ■ Steepest gradient descent


- začneme v náhodném bodě  $(a, b)$
- spočítáme parciální derivace chybové funkce  $\frac{de}{da}$  a  $\frac{de}{db}$
- vektor  $(\frac{de}{da}(a), \frac{de}{db}(b))$  se nazývá **gradient**
- posuneme náš odhad  $(a, b)$  opačným směrem a opakujeme
- (tedy  $\frac{de}{da}(a)$  říká, kam máme posunout parametr  $a$ )
- ( $\frac{de}{db}(b)$  říká, kam máme posunout parametr  $b$ )
- obě derivace nulové = jsme v lokálním minimu
- a tedy chyba je nejmenší možná
- (v některých příznivých situacích)

## ■ Totéž lze dělat pro libovolnou funkci a libovolný počet dimenzí

# Steepest gradient descent




# Neuron



**výpočet:**  $Z = x_1 w_1 + x_2 w_2 + \dots + x_n w_n + w_0$   
(neuron je tedy jednoduchá lineární funkce)

**trénování:** optimalizace ( $w_0..w_n$ ) pomocí steepest gradient descent

# Neuronová síť



# Trénování neuronové sítě

- Backpropagation: algoritmus zpětné propagace chyby
  - začneme s náhodnými vahami  $w_{ij}$
  - provedeme výpočet na trénovacích příkladech
  - provedeme gradient descent a úpravy parametrů  $w_{ij}$
  - opakujeme, dokud nedosáhneme minima (nulových derivací podle všech parametrů  $w_{ij}$ )
- Proč „zpětná propagace“
  - chyba  $e$  je složená funkce
  - derivace složené funkce je součinem derivací jejích částí
  - např. pro  $\frac{de}{dw_{11}}$  musíme tedy nejdřív spočítat  $\frac{de}{dz}$
  - potom  $\frac{df_3}{dy_1}$  a  $\frac{df_3}{dy_2}$
  - a nakonec  $\frac{df_1}{dw_{11}}$ ,  $\frac{df_1}{dw_{12}}$ , ...,  $\frac{df_2}{dw_{21}}$  atd.
  - postupujeme tedy zprava doleva, opačně než výpočet